

人工神经网络的学习算法(1)

张鸿宾 (北京计算机学院)

摘要

人工神经网络可以看作是一种具有学习和自我组织能力的智能机器。最近几年,由于出现了一些强有力的学习算法,大大推动了有关神经网络的理论和应用研究。本文介绍并分析其中几个有代表性的学习算法。

关于智能机器的制造方法,很早以来一直有两种不同的策略在互相竞争着。第一种是以逻辑为基础的,认为只有符号运算才称得上是所谓智能的本质。这种策略是在通常的串行计算机上实现的,在专家系统和计算机博弈等领域中取得了很大的成功。但在处理和外部世界有较多联系的对象,诸如图像处理 and 声音、物体识别,以及常识推理等时,却显得能力不强,暴露出其局限性。

第二种策略是试图模仿人脑的信息处理机制,通过把大量的结构非常简单的计算单元(神经元)相互连接起来,构成人工神经网络,实现高度并行和分散的信息处理,用来进行物体和声音识别、联想存储和常识推理等。这种神经网络型计算机不需要编写程序,它可以从示例中进行学习,实现网络的自我组织。比起第一种策略来,这种策略在

过去一些年进展不大,成果也不怎么显著。究其原因,主要有以下两点。一是过去的神经网络学习算法不够完善和强有力,信息表现的方式也不适当。二是在通常的串行机上模拟神经网络的效率非常低。然而,随着VLSI和CAD技术的进步,神经网络的硬件实现已经变得较为容易了。特别是由于近几年提出了一些强有力的学习算法,使得一度沉寂的神经网络型计算机的研究又出现了一个新的高潮。人们期待这个一度落后了的“小兄弟”能够成长起来,和“老大”——串行数字机携手,在未来的智能机器中发挥更大的作用。

本文在回顾以往的神经网络学习算法的基础上,介绍和分析最近几年新提出的两个主要学习算法——误差反向传播算法和Boltzmann Machine的学习算法,展望它们的

System Processor, Product Description,
TRW MEAD AI Center, San Diego,
1987

[26] R. W. Kuczewski, et al, "Neurocomputer Workstations and Processors: Approaches and Applications", *IEEE ICNN Conf.*, 1987.

[27] J. Prichett, "The New Cybernetics: ADAPting to AI", *TRW Message s*,4(1).

1986.

[28] L. D. Jackel, et al, "Electronic Neural Networks", in *Proc. of Supercomputing'88*, pp.41-46.

[29] L. D. Jackel, et al, "Electronic Neural Networks Chips", *Applied Optics*, 26, 1987.

[30] 蔡义发,丁德恒,吕维雪,电子神经计算机的设计与实现,《计算机学报》(待发表)。

一些可能应用并提出一些需要进一步探讨的问题。

一、神经网络的学习

神经网络的功能是由它的基本构成单元(以下称为神经元或网络的节点)的输入输出特性以及神经元之间连接的方式确定的。为了使网络能够执行一定的信息处理任务,我们必须规定网络的形态和各种参数,即规定神经元的输入输出特性(神经元的类型)、网络的连接方式,并设置各个神经元之间连接权的大小。

确定神经元之间连接权大小的方法目前主要有两种。一种是从所要解决的问题的定义中直接计算神经元之间的连接权。例如,当我们用Hopfield网络求解最优化问题时,可以令问题的评价函数和网络的能量函数一致,然后可以直接计算出各个连接权的大小。

另一种情况是,事先我们无法知道各个连接权的适当值,或者人为地设置各个连接权太繁琐的时候,必须使用“学习”的方法,或者称为网络的“自组织”方法。所谓神经网络的学习,就是通过给网络各种训练范例,把网络的实际响应和所希望的响应进行比较,然后根据偏差的情况修改各个连接权,使网络不断朝着能正确动作的方向变化下去,直到能得到正确的输出为止。如何根据偏差来确定各个连接权的修正量,这就是神经网络学习算法所要解决的问题。由于学习算法的优劣直接影响到神经网络求解问题的能力,所以有关神经网络学习算法的研究一直受到人们的重视。每当新的强有力的学习算法出现后,神经网络的理论和应用研究就应前迈进了一大步。

二、Perceptron和最小二乘的学习算法

Perceptron型网络是Rosenblatt在1958年提出的一种模式识别机^[1]。它由S、A、R三层神经元组成。同一层内的神经元之间没有相互连接,不同层间也没有反馈。有学习能力的只是中间的A层和最后的R层之间的连接权。从这个意义上说,Perceptron实际上相当于一层有学习能力的神经网络(图1(a))。最早的Perceptron的神经元是二值的,输入输出特性是阈值型的(图1(b))。由于输出层的节点是互相独立的,所以只要考虑一个节点就可以了。R层的第j个节点所接受的总输

入 U_j^R 和输出 O_j^R 分别为:

$$U_j^R = \sum_i W_{ij} O_i^A$$

$$O_j^R = f(U_j^R)$$

式中 W_{ij} 是A层的第i个节点和R层的第j个节点间连接的权。 f 是阈值型函数(图1(b)):

$$f(x) = \begin{cases} 1 & \text{当 } x \geq 0 \text{ 时} \\ 0 & \text{当 } x < 0 \text{ 时} \end{cases}$$




图1 Perceptron型网络及其输入输出特性

当把Perceptron型网络用作模式分类机时,在S层上给定某个输入模式(0, 1的符号串)后,我们希望在R层上能够判定这个模式所属的类别。

这种网络的学习算法是^[2],先用各种模式对网络进行训练,当发生错误时,根据偏差来修改A层和R层之间连接权的大小。这是一种有教师的误差校正型学习方法。

设在t时刻的输入模式为 $X_s = (x_{s1}, x_{s2}, \dots, x_{sn})$, R层的神经元j对于 X_s 的正确输出设为 Y_{sj} ,把A层的神经元i的输出记为 $O_i^A(s, t)$, R层神经元j的实际输出记为 $O_j^R(s, t)$ 。那么,连接权 W_{ij} 可以按以下的方法加以修正:

$$W_{ij}(t+1) = W_{ij}(t) + (Y_{sj} - O_j^R(s, t)) \cdot O_i^A(s, t)$$

式中 Y_{sj} 称为教师信号, $(Y_{sj} - O_j^R(s, t))$ 称为学习信号或误差信号。

对于上面的学习算法,可以证明下面的

收敛定理成立^[1]。

定理1 当输入模式是线性可分时，上述学习算法可以在有限次收敛。这时所得到的各个连接权，能对所有的输入模式进行正确的分类。

上述的网络只能解决线性可分模式的分类问题。对于线性不可分问题，我们希望连接权能在误差的最小二乘意义下收敛。即网络的连接权能收敛到使下式的误差E达到最小：

$$E = \frac{1}{2} \sum_{i=1}^n (Y_{s,i} - O^R_i(s))^2$$

只要对上面简单Perceptron网络稍加修改，把神经元由二值型改为连续取值，把输入输出特性由阶跃函数改为其它的单调递增函数，使用下面的连接权调整公式

$$W_{ij}(t+1) = W_{ij}(t) + e(Y_{s,i} - O^R_i(s, t)) \frac{dO^R_i(s, t)}{dU^R_i(s, t)} \cdot O^A_i(s, t)$$

就能保证网络的连接权近似地收敛到使E最小的值。式中 dO^R_i/dU^R_i 为神经元i的输出对输入的导数。 e 为每步修正时的系数。

上述的学习算法实质上是连接权空间上的梯度下降法。当神经元的输入输出函数是单调时，定义在连接权空间上的误差曲面是椭圆抛物面，其水平断面是椭圆状，垂直断面是抛物线状，且最(极)小值只有一个。在这种情况下，梯度下降法是一种有效的方法。由于误差曲面的谷底一般较为平坦，可以预想算法的收敛速度将会很慢。必须小心地选择 e 的大小以加快收敛速度并防止振动。

应当指出，Perceptron型网络的能力是有一定限度的。它们所能形成的判决区域只能由一个超平面来规定。有不少的问题，无论怎么调整连接的权，都不能实现输入和输出模式间正确的变换。例如，当我们试图用两个输入节点、一个输出节点的网络来作“异或”运算时，即当输入是(0, 1)和(1, 0)时输出1，当输入为(1, 1)和(0, 0)时输出0，这个网络无论怎样调节连接权和阈值，

都不能胜任这个问题。对于Perceptron的能力和限度，Minsky和Papert在他们的书中作过相当透彻明瞭的分析^[1]。

为了提高神经网络的能力，可以把几层网络级联起来。关于多层网络的能力，可以证明有下面的完全性定理。

定理2 假定中间层节点可以根据需要自由设置，那么用三层的阈值型网络可以实现任意的二值逻辑函数。

定理3 假定中间层节点可以根据需要自由设置，那么用三层S状的输入输出特性的节点，可以以任意精度近似任何连续函数^[2, 5]。

把几层网络级联在一起时，中间层的神经元由于不直接和输入输出节点相连接，所以又叫作隐蔽节点。隐蔽节点可以用来学习输入模式各种有用的内部表示，大大提高了网络的功能。但是当人们试图把上面的误差校正型学习算法推广到多层网络上时，却遇到了很大的困难。由于有大量的和输出并无直接联系的隐蔽节点存在，当输出有误差时，如何判断这究竟是哪个神经元的“过错”呢？我们该调整哪个连接权呢？由于有这些难点，不少的人甚至怀疑对于多层网络来说不存在这样的学习算法。直到1986年由Rumelhart、Hinton和Williams提出了多层网络的误差反向传播算法后(差不多同时LeCun以及Parker也各自独立地提出了类似的算法)，多层网络的学习才有了重大进展，并随之出现了一大批引人注目的应用成果。下面一节我们以Rumelhart等人的算法为例^[6]，说明多层网络的学习算法。

三、多层网络的误差反向传播算法

这个算法的主要思路是，如果我们能求出误差E对各个神经元输出的偏导数，那么就可以算出E对所有的连接权的偏导数，因而可以利用梯度下降法来修改各个连接权。如果没有隐蔽节点，这很容易作到。因为要调整的连接权都和输出节点直接相连，E对各个输出节点的偏导数可以从E的定义中直接计

算出来。当有隐蔽节点存在时,问题就变得复杂了,但我们可以利用阶层型网络的特点,设法从输出层开始,反方向地、一层一层地把E对每个节点输出的偏导数求出来,从而确定E对各个连接权的偏导数。下面我们具体地分析一下网络的学习过程。

假定有一个M层的阶层型网络。把第K层的第i个节点记为 U_i^K 。 U_i^K 的输入是 i_i^K ,输出是 O_i^K 。输入输出函数记为f, $O_i^K = f(i_i^K)$ 。从 U_i^K 到 U_i^{K+1} 的连接权为 $W_{i,j}^{K+1}$ 。设 θ_i^K 为 U_i^K 的阈值。 θ_i^K 的大小也可以学习。它的学习规则可以通过增设节点,转化为和连接权同样的学习方式。

对于输入模式P,如果输出层M的第j个节点的实际输出为 O_j^M ,正确的输出应该为 Y_j 的话,那么误差 E_p 可以定义为:

$$E_p = \frac{1}{2} \sum_j (Y_j - O_j^M)^2$$

为了减小误差 E_p ,根据梯度下降法, $W_{i,j}^{k+1}$ 的修正量 $\Delta W_{i,j}^{k+1}$ 为:

$$\Delta W_{i,j}^{k+1} = -\varepsilon \frac{\partial E_p}{\partial W_{i,j}^{k+1}}$$

式中 ε 为修正系数。把上面的偏导数展开,有

$$\frac{\partial E_p}{\partial W_{i,j}^{k+1}} = \frac{\partial E_p}{\partial i_j^k} \frac{\partial i_j^k}{\partial W_{i,j}^{k+1}} = \frac{\partial E_p}{\partial i_j^k} O_{i,j}^{k+1}$$

当 $k=m$ 时,由 E_p 的定义有

$$\frac{\partial E_p}{\partial i_j^m} = \frac{\partial E_p}{\partial O_j^m} \frac{\partial O_j^m}{\partial i_j^m} = -(Y_j - O_j^m) \cdot f'(i_j^m)$$

当 $k \neq m$ 时,有

$$\begin{aligned} \frac{\partial E_p}{\partial i_j^k} &= \sum_l \frac{\partial E_p}{\partial i_l^{k+1}} \cdot \frac{\partial i_l^{k+1}}{\partial O_j^k} \cdot \frac{\partial O_j^k}{\partial i_j^k} \\ &= \sum_l \frac{\partial E_p}{\partial i_l^{k+1}} \cdot W_{j,l}^{k+1} \cdot f'(i_j^k) \\ &= f'(i_j^k) \sum_l \frac{\partial E_p}{\partial i_l^{k+1}} \cdot W_{j,l}^{k+1} \end{aligned}$$

把上面各式加以整理,可以得到连接权 $W_{i,j}^{k+1}$ 的修正量的公式为:

$$\Delta W_{i,j}^{k+1} = -\varepsilon d_j^k O_{i,j}^{k+1}$$

式中 $d_j^k = \partial E_p / \partial i_j^k$ 。当 $k=m$ 时,

$$d_j^m = (O_j^m - Y_j) \cdot f'(i_j^m)$$

$$k \neq m \text{ 时, } d_j^k = f'(i_j^k) \cdot \sum_l W_{j,l}^{k+1} \cdot d_l^{k+1} \quad (k=m-1, \dots, 2)$$

上式中的 d_j^k 可以看作是一般化的误差信号。它的计算是从 $k=m$ 开始,到 $k=2$ 逆推地进行的。最后一式中的 $\sum_l W_{j,l}^{k+1} \cdot d_l^{k+1}$,就好象把在输出层所产生的误差信号 d_j^m 从输出层开始,以相反的方向,加权求和后一层层地传向输入层。这就是这种学习算法之所以叫作误差反向传播算法的由来。

如果网络所有节点的输入输出函数都是对数型的话,即

$$f(x) = 1 / (1 + \exp(-x + \theta))$$

由于 $f'(x) = f(x)(1 - f(x))$,因此

$$f'(i_j^k) = O_j^k (1 - O_j^k)$$

这是常常使用的一个公式。

在实际使用前面的学习算法时,为了加快收敛的速度,减小振荡,可以采用如下的修正量公式:

$$\begin{aligned} \Delta W_{i,j}^{k+1}(t+1) &= -\varepsilon d_j^k O_{i,j}^{k+1} + \alpha \\ &\Delta W_{i,j}^{k+1}(t) \end{aligned}$$

式中的 α 为一小的正数, t 表示学习的次数。

要注意的是,当网络含有隐蔽节点时,其误差曲面的极小值可能不只一个。和一般的梯度下降法一样,上述的学习算法也有可能收敛到某个极小值上。

下面我们以一个能检测模式对称性的网络为例,说明如何利用上面的学习算法进行网络的自我组织。这个例子非常有趣,网络的学习结果是我们事前所不曾料到的,仔细分析后又觉得网络学习的结果非常合理。

对于一个由0和1组成的模式串,我们希望用一个两层网络来判别它是否是中心对称的。例如,对一个六位长的模式串,当输入模式为010010或100001等中心对称模式时,网络的输出应为1。对010001、100100等非中心对称模式,网络的输出应为0。很明显,这是一个线性不可分问题。所使用的网络如图2所示,由6个输入节点、两个隐蔽节点和一个输出节点组成。每个节点是连续取值的。输入输出特性是对数型的。通过学习,我们希望找到一组适

当的连接权和节点阈值来解决这个问题。

把输入模式加在输入节点上后,使网络动作起来,计算实际输出和正确解之间的误差,然后利用上面的学习算法进行连接权的修正。连接权的初始值可以随机设置在 -0.3 到 0.3 之间。经过一千次左右的学习后,所得到的连接权和节点阈值如图2所示。

从图中的结果可以看出,所得到的连接权非常有趣。它们是左右镜像对称和上下镜像对称的,大小相等,符号相反。另外,连接权的大小之间有一个近似的 $1:2:4$ 的关系。这使得输入节点的左3个或右3个节点的8种输入模式都以不同的值输入给隐蔽节点。当对称模式输入时,两个隐蔽节点的输出为0,输出节点的输出是1。当输入模式的中心对称性一旦破坏时,两个隐蔽节点之中至少有一个输出为1,因而网络的输出是0。上面的结果说明,通过学习,网络自身形成了一个非常有效的内部结构。这个内部结构的巧妙,甚至是我们事先所不曾料到的。

误差反向传播算法提出来以后,在模式识别、图像处理、数据压缩和人工智能等方面都取得了一批很有意义的研究成果。如Sejnowski和Rosenberg提出的把英文单词转换为发音记号的NET talk网络^[7],Sejnowski等人的识别海底岩石和潜水艇的声纳反射音的网络系统等,都取得了相当引人注




图2 求解中心对称的网络

目的成果。限于篇幅,这里就不准备介绍这个算法的一些实际应用了。

目前,误差反向传播算法的理论和应用还有不少的问题值得进一步研究。从收敛性上看,只要每一步的修正量十分小的话,虽然可以收敛到误差平方和意义上的极小值点,但不能保证一定得到最小

解。虽然在实践中有一些避开极小解的方法,但缺乏理论上的定量分析。从收敛速度上看,对小规模的问题还可以,对大规模的问题则相当慢。已经有人提出了一些加快收敛的方法^[8,9]。另外,从少量的样本中学习的结果是否具有一般性问题,也是传统模式识别理论中的一个难题。还有,从实际应用上看,中间层的隐蔽节点设置多少合适,如何设置等问题,也是值得研究的课题。目前是凭直感来进行的。有些实验说明,过多的中间层节点反而招致网络性能下降。所有以上这些问题,都有待于进一步的研究和实践。

参考文献

- [1] F. Rosenblatt, The perceptron: a probabilistic model for information storage and organization in the brain, Psychol. Rev., 65-6, 386-408, 1958.
- [2] F. Rosenblatt, Principles of Neurodynamics—Perceptrons and the Theory of Brain Mechanisms, 1961.
- [3] M. Minsky, and S. Papert, Perceptrons, 1969.
- [4] B. Irie, and S. Miyake, Capabilities of three-layered Perceptrons, Proc. of IEEE ICNN88 1988.
- [5] 船橋賢一, ニューラルネットワークのCapability について (On the Capability of neural network), (日本)電子情報通信学会技術報告, MBE88-52, 1988.
- [6] D. E. Rumelhart, et al, Learning internal representations by error propagation, In Parallel Distributed Processing, Vol.1, 1986.
- [7] T. J. Sejnowski, and C. R. Rosenberg, Parallel networks that learn to pronounce English text, Complex System, 1, 145-168, 1987.
- [8] 木本隆, ほか, ニューラル・ネットワークの学習方式の検討, 昭和63年度人工知能学会全国大会论文集, pp.123-124, 1988.
- [9] L. P. Ricotti, S. Ragazzini, and G. Martenelli, Learning of word stress in a sub-optimal second order back-propagation neural network, Proc. of IEEE ICNN 88, 1988.